基于三种深度学习模型在前列腺癌放疗中生成 sCT 的质量研究

付文胜 [1]，黎国全 [1]，丁泽宇 [1]，庞博 [2]，杨志勇 [3]，吴喜军 [1*]
[1] 南华大学核科学技术学院，湖南衡阳 421001；
[2] 武汉大学物理与技术学院医学物理系，湖北武汉 430072；
[3] 华中科技大学同济医学院附属协和医院肿瘤中心，湖北武汉 430022

[*]通讯作者:吴喜军，邮箱:wuxijunusc@163.com;

摘要：
目的：放疗过程中的锥形束 CT(cone beam CT，CBCT)可为患者提供更精确的靶区定位，但由于散射线多造成的对比度低、噪声大、伪影大等，导致影像质量较差，在实时放疗中无法用于剂量计算。本研究旨在使用 Unet、CyclaGAN 和 CGAN 等三种深度学习网络生成基于 CBCT 的合成 CT(sCTs)，研究并对比三种 sCTs 的图像质量。
方法：使用 78 例前列腺癌患者的 CBCT 和计划 CT(pCTs)数据，进行预处理后，其中 63 例为训练集，10 例为测试集，5 例为验证集，分别训练和评估基于三种模型的图像质量。使用平均绝对误差(MAE)、平均误差(ME)、均方误差(MSE)、峰值信噪比(PSNR)、结构相似性(SSIM)和空间非均匀性(SNU)等影像评估指标以及频域信息进行评估。
结果：在三种模型中，cGAN 模型在各个指标上都表现出最优的性能。在全局条件下的图像质量方面，平均 MAE 降低到 7.77HU, MSE 降低到 4.99，PSNR 提高到 54.95，SSIM 提高到 96%。
结论：应用深度学习方法可以大幅修正 CBCT 的 HU 值并生成对应高质量的 sCT，针对前列腺癌的病人，CGAN 模型生成的 sCT 拥有更好的影像质量，使用该模型生成基于 CBCT 的 sCT 可以为前列腺癌放疗靶区剂量计算提供。

关键字：放射治疗，图像验证，深度学习，前列腺癌，合成 CT

Quality comparison of sCT generation by three deep learning models in prostate cancer radiotherapy

Fu Wen-Sheng[1]，Li Guo-Quan[1]，Ding Ze-Yu[1]， PANG Bo[2]， Yang Zhi-Yong[3]， WU Xi-Jun[1 *]
[1] School of Nuclear Science and Technology， University of South China， Hengyang 421001， China；
[2] Department of Medical Physics， School of Physics and Technology， Wuhan University， Wuhan 430072， China；
[3] Cancer Center， Union Hospital Affiliated to Tongji Medical College， Huazhong University of Science and Technology， Wuhan 430022， China

[*] Corresponding author: Wu Xijun， Email:wuxijunusc@163.com；

Abstract:
Objective: Cone beam CT（CBCT）can provide more accurate target location for patients during radiotherapy. However， due to the low contrast， loud noise and large artifacts caused by many scattered lines， the image quality is poor， and it cannot be used for dose calculation in real-time radiotherapy. This study aims to generate CBCt-based synthetic CT（sCTs） using three kinds of deep learning networks， namely Unet， CyclaGAN and CGAN， and study and compare the image quality of the three sCTs.
Methods: The CBCT and pCTs data of 78 patients with prostate cancer were preprocessed， including 63 training sets， 10 test sets， and 5 validation sets， to train and evaluate the image quality based on the three models， respectively. Image evaluation indexes such as mean absolute error （MAE）， mean error （ME），mean square error（MSE），peak signal-to-noise ratio（PSNR），structural similarity （SSIM） and spatial non-uniformity （SNU） and frequency domain information were used for evaluation.
Results: Among the three models， CGAN model showed the best performance in each index. In terms of image quality under global conditions， the average MAE is reduced to 7.77HU， MSE is reduced to 4.99， PSNR is increased to 54.95， SSIM is increased to 96%.
Conclusion: The deep learning method can significantly modify the HU value of cbct and generate the corresponding high-quality sCT. For patients with prostate cancer， the sCT generated by cGAN has better image quality. The CBCt-based sCT generated by this model can provide the target dose calculation for prostate cancer radiotherapy.

Keywords: radiation therapy， image validation， deep learning， prostate cancer， synthetic CT

1. 介绍

核技术在医学领域的应用非常广泛，可以用来消毒，扫描，了解血液情况，杀灭肿瘤等，达到对疾病的预防、诊断和治疗的目的。放射治疗就是利用治疗机或加速器产生的 X 射线、电子线、质子及其他粒子束等治疗恶性肿瘤的方法。

放射治疗的总原则是在达到最大限度对肿瘤杀灭的同时，把对正常组织的损伤降到最低，以提高放疗疗效，减少后遗症。因此，在放疗过程中，确保照射区和肿瘤区的重合性决定了放疗的疗效。在整个放射治疗过程中，解剖结构的改变可能导致治疗靶区覆盖面积减少和正常组织的受照射剂量增加，从而影响放射治疗的疗效[1]。为保证放疗靶区的准确，我们采用笔形束 CT(ConeBeam CT, CBCT)来矫正靶区位置，在偏差较大或者肿瘤体积变化较大时，需要实时调整靶区位置和剂量。然而，CBCT 影像的 HU 值与 CT 有较大偏差，噪声过大，不能直接用于剂量计算[2]。所以我们需要对 CBCT 影像进行处理并生成可以用于剂量评估和计算的合成 CT(Synthetic CT, sCT)。

目前，深度学习已经成为图像到图像转换的通用解决方案，而且，在不知道 CBCT 映射函数的情况下，深度学习是一种很快速的将 CBCT 转换为 CT 图像的新方法。使用深度学习方法进行图像到图像转换的一种方法是使用成对图像进行监督训练，另一种方法是使用未配对图像进行无监督训练。在本研究中，我们的目标是在保持 CBCT 解剖结构的同时，从 CBCT 图像合成具有 CT 图像质量的 CT 图像，使生成的 sCT 图像与 CBCT 保持完全相同的解剖结构，同时具有计划 CT(plan CT, pCT)的 HU 精度。我们将三种深度学习模型:循环一致生成对抗网络(Cycle-Consistent Generative Adversarial Network, CycleGAN)、条件生成对抗网络(conditional Generative Adversarial Network, CGAN)和 U 型网络(Unity Networking, Unet)的性能进行了比较，并通过指标量化分析了这三种深度学习方法生成的图像的 HU 精度。

2. 材料与方法

2.1 数据

78 例前列腺患者的 pCT 和 CBCT 图像分为训练集 63 例，验证集 5 例和测试集 10 例。CBCT 由 Varian halcyon 放疗直线加速器(Varian Medical Systems, Palo Alto, CA, USA)在线验证影像系统采集，体素重建大小为 0.55 × 0.55 mm^2，层厚为 2mm，层间距为 2mm，分辨率为 512 ×512。pCT 图像由 Philips CT 扫描仪采集，采用多层采集方式，体素间距为 0.6 × 0.6 mm^2 ，层厚为 3.00 mm，层间距为 3mm，分辨率为 512 × 512。使用内存为 12GB 的 NVIDIA GTX 3060 Ti 显卡对数据集进行学习、训练。

为了进行测试，通过以下步骤生成了作为网络学习输出端金标准的形变 pCT (deformed CT, dCT)。使用开源图像配准工具箱 Elastix (Klein et al . 2010)将 pCT 与 CBCT 进行形变配准，生成 aCT 图像，作为评估患者研究 sCT HU 值准确性的基础真值。再将 aCT 与 CBCT 进行除床操作后刚性配准生成用于训练的 dCT，并裁剪成 512 x 512 大小的图像。训练数据集中的所有图像归一化到[-1,1]范围用于网络学习。在训练阶段，epoch 设置为 500，在每个 epoch 随机切换 CBCT 和 CT 切片，以去除与患者的对应关系。验证数据集用于超参数调优，测试数据集用于模型测试。

2.2 模型介绍

目前有两种主流的深度学习方法被用来进行训练从 CBCT 生成 sCT。第一个是 Unet 模型，该模型已被广泛研究，并证明可以使用跳过连接有效地融合低分辨率和高分辨率信息。它可以抑制 CBCT 中的全局散射和局部噪声，并将其转换为具有精确 CT 数的 sCT [3-6]。第二个是 CycleGAN 模型，该模型通过在鉴别器和生成器之间获得对抗反馈，在生成更真实

的 sCT 方面具有理论优势。[7-12]然而，Unet 模型主要关注学习计划 CT (pCT)值，可能导致 sCT 图像模糊，软组织分辨率较低；虽然 CycleGAN 模型可以通过图像域的无监督学习提高图像保真度和软组织分辨率，但由于对周期一致性的要求，可能会保留 CBCT 伪影等强特征。因此，Zhang 等人[12]引入一种新的条件生成对抗网络(conditional Generative Adversarial Network, CGAN)模型，该模型将图像条件整合到生成对抗网络架构中，用于网络监督和训练 。

2.2.1 Unet 模型

Unet 模型是一个经典的图像分割网络，模型如图 1 所示。该网络是左右对称的，左侧是用来获取特征信息的压缩路径，右侧是精准定位的拓展路径，在跳跃连接部分使用拼接操作进行特征融合。其卷积结构统一为 3×3 的卷积核，填充为 0，网络中没有全连接操作。因其具有灵活简单的优点，在样本数据较少时也可以获得较好的分割效果[14]。

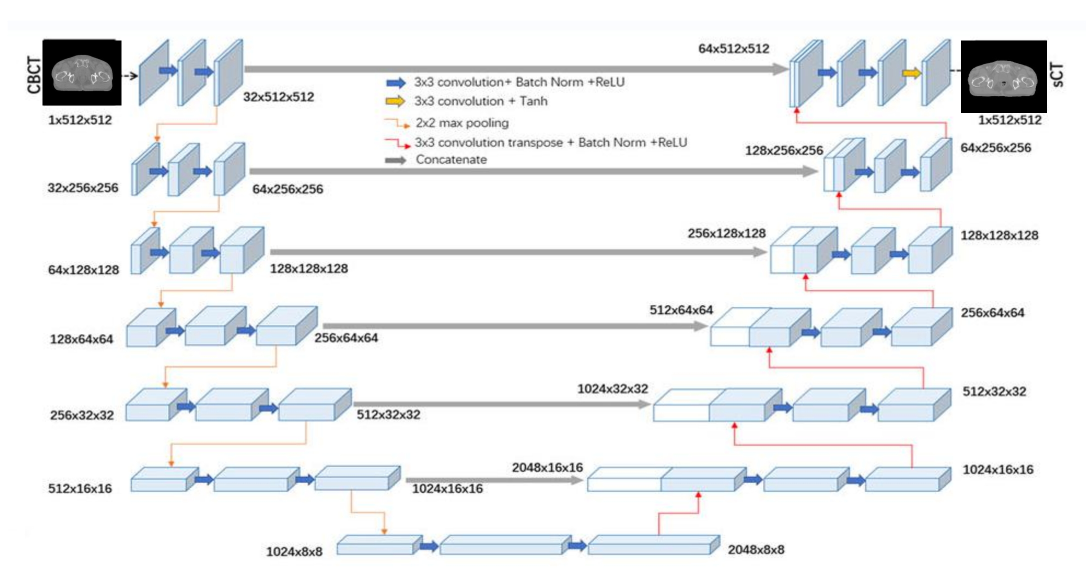


图 1.Unet 模型流程图

使用 Unet 模型训练时，采用平均绝对误差(MAE)和结构不相似度(DSSIM)的组合作为损失函数，采用 Adam 优化算法，500 个训练 epoch 的学习率为 0.0001。

MAE 和 DSSIM 的方程定义如下:

$$MAE(sCT, dCT) = \frac{1}{M}\sum_{i,j}^{M} |sCT(i,j) - dCT(i,j)|, \#(1)$$

$$DSSIM(sCT, dCT) = 1 - \frac{(2\mu_{sCT}\mu_{dCT} + c_1)(2\sigma_{sCT,dCT} + c_2)}{(\mu_{sCT}^2 + \mu_{dCT}^2 + c_1)(\sigma_{sCT}^2 + \sigma_{dCT}^2 + c_2)}, \#(2)$$

式中，M 为图像中的总像素数，μ和σ为平均值和标准差，其中σ(A, B)为 A、B 两幅图像的协方差，cl= $[(0.01L)]^2$, c2= $[(0.03L)]^2$, L 为 dCT 图像中像素值的动态范围。Unet 的最终损失函数如式 3 所示:

$$Loss_{Unet} = \alpha MAE(sCT, dCT) + (1-\alpha)DSSIM(sCT, dCT), \#(3)$$

其中α为 MAE 与 DSSIM 之间的平衡系数，设为 0.75。

2.2.2 CycleGAN 模型

CycleGAN 模型是一种实现图像风格转换功能的生成对抗网络，它可以在两种类型图像之间进行转换而不需要对应的关系! CycleGAN 方法[12]是由两个 GAN 组成，模型如图 2 所示。通过生成器和鉴别器的对抗性反馈，分别学习两个图像域的正向和反向映射。生成器

使用 9 个残差块，并使用 70x70 PatchGAN 作为鉴别器，将最终特征映射矩阵中的每个像素与原始图像中的 70x70 像素进行匹配以对其进行认证。

在本研究中，两个图像域 X 和 Y 相对的是 CBCT 和 dCT。因此，生成器 Gxy 的目的是将 CBCT 转化为 sCT，使其与真实的 dCT 保持一致。然后使用鉴别器 Dy 来区分 sCT 和 dCT，从而产生对抗性损失：

$$L_{GAN}(G_{XY}, D_Y, X, Y) = \mathbb{E}_{y\sim p_{data}(y)}[log D_Y(y)] + \mathbb{E}_{x\sim p_{data}(x)}[log(1 - D_Y(G_{XY}(x))]. \# (4)$$

然后将生成的 sCT 通过生成器 Gyx 转换回 CBCT 域，即 CycleCBCT，并通过循环一致性损失保证两个图像域之间的学习。该网络训练了 200 次，学习率为 0.0002。

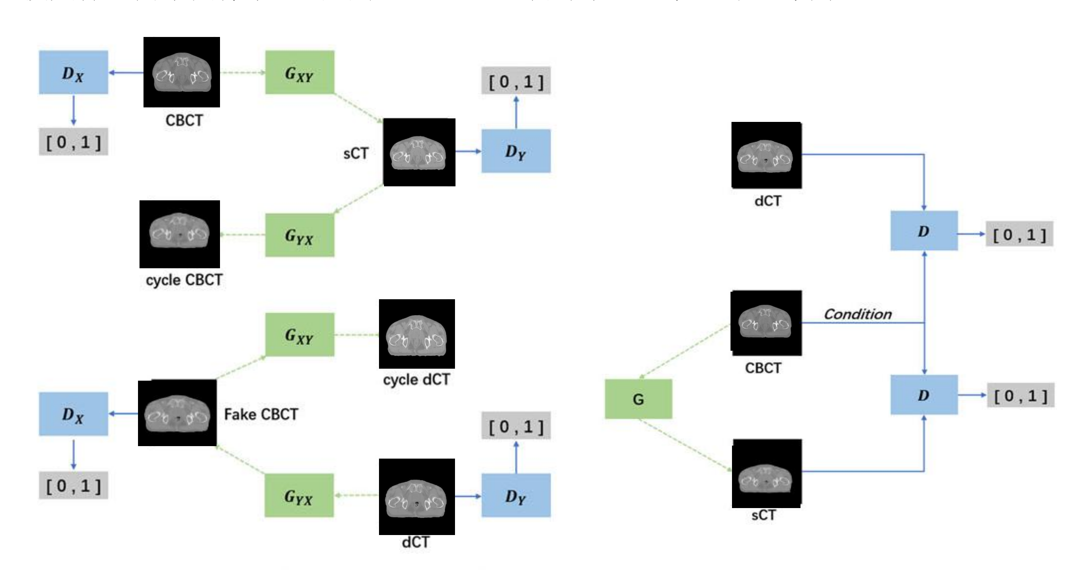


图 2.CycleGAN 模型流程图　　　　图 3.CGAN 模型流程图

2.2.3 CGAN 模型

CGAN 模型如图 3 所示。CGAN 不需要周期一致性，因此不会保留 CBCT 的强伪特征，并将 CBCT 作为判别器的条件输入来增强网络学习。CGAN 的发生器和鉴别器与前述 CycleGAN 的发生器和鉴别器一致，便于后续比较。由 CGAN 从 CBCT 生成的 sCT 与 CBCT 连接后，会受到鉴别器的判断，产生对抗性损失。除了对抗损失外，CGAN 还使用 L1 损失进行训练。CGAN 损失函数如下所示：

$$L_{cGAN} = \mathbb{E}[log D(CBCT, dCT)] + \mathbb{E}\left[log\left(1 - D\big(CBCT, G(CBCT)\big)\right)\right] + \lambda\mathbb{E}[\|dCT - G(CBCT)\|_1], \# (8)$$

其中λ设为 100。CGAN 训练 500 次，学习率为 0.0001。

2.3 评估

鉴于所有的图像相似性指标都只对病人的轮廓内体素进行计算，本文利用 MATLAB 和 PYTHON 软件对 sCT 和 pCT 进行处理，并在全局和局部条件下对不同方法生成的 CBCT 和 sCT 的图像质量和 HU 精度进行了评价。局部评价提取的高对比度区域和低对比度区域如图 4(a)所示，计算 SNU 所选取的骨组织和软组织区域如图 4(b)所示。评价指标为 MAE、结构相似度(SSIM)、峰值信噪比(PSNR)和空间非均匀性(SNU)。使用 MAE 计算两幅图像中所有像素值的平均绝对误差，定义为式 1。用于比较结构信息的 SSIM 定义为：

$$SSIM = 1 - DSSIM, \# (9)$$

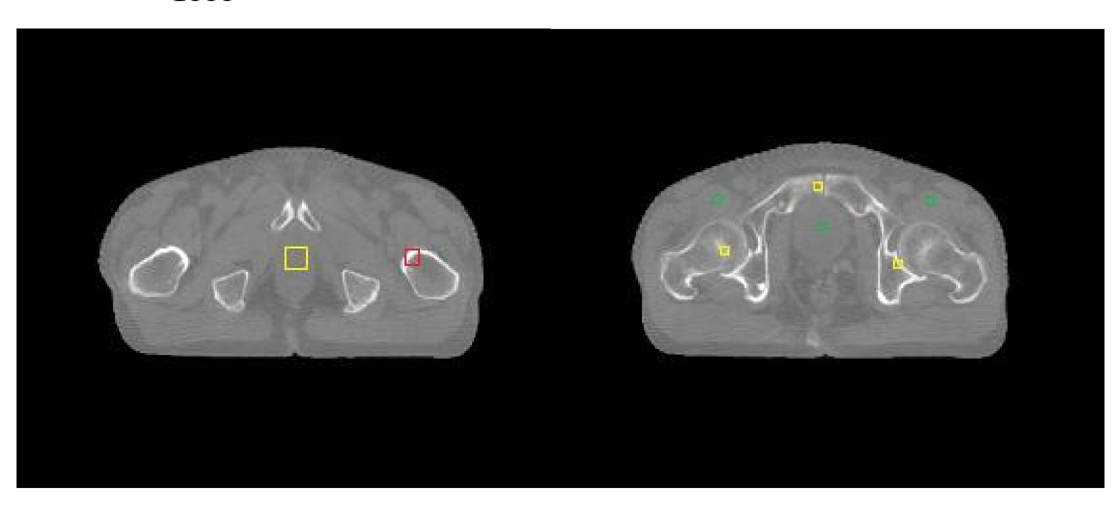
其中 DSSIM 定义为式 2。PSNR 用于评价图像质量，特别用于降噪，定义为:

$$PSNR(sCT, dCT) = 20 \times log_{10}(MAX) - 10 \times log_{10}\big(MSE(sCT, dCT)\big), \# (10)$$

$$MSE(sCT, dCT) = \frac{1}{M}\sum_{i,j}^{M} |sCT(i,j) - dCT(i,j)|^2, \# (11)$$

其中 MAX 是 sCT 或 CBCT 中的最大像素值。空间非均匀性定义为感兴趣区域内最大和最小平均 HU 的差值来进行比较。

$$SNU = \frac{\overline{HU}_{max} - \overline{HU}_{min}}{1000}, \# (12)$$



a　　　　　　　　　　　　　　　b

图 4. a.sCT 低对比度区和高对比区的选取，黄色代表低对比度区，红色代表高对比度区。b.骨组织和软组织区域的选取，黄色代表骨组织区，绿色代表软组织区。

3. 结果

所有测试 sCT 图像和 CBCT 图像的定量评价结果见表 1。从整体评价来看，cycleGAN 的 MAE 降低到 22.73±2.34 HU, SSIM 增加到 0.88±0.01，PSNR 增加到 47.77±0.68，而 Unet 的 MAE 分别为 8.64±1.49 HU，效果更好，SSIM 为 0.96±0.01，PSNR 分别为 52.72±1.48。此外，cGAN 在所有指标上都获得了最好的性能，MAE 为 7.77±1.32 HU, SSIM 为 0.96±0.01，PSNR 为 54.95±1.48 dB，表明其在生成高质量 sCT 图像方面具有优势。平均误差和均方误差代表合成 CT 与计划 CT 间的区别，值越小，模型的学习效果就越好。

对于局部的测试，高对比度区域得到出与全局评估基本一致的结果，CGAN 模型在各种指标上都表现出优异的性能。然而，在低对比度区域，Unet 模型在各项指标上均优于 GAN 模型。

此外，如表 3 所示，CGAN 模型极大的减小了组织的空间不均匀性，增强了 sCT 图像的对比度，而 Unet 模型造成了模糊效应，导致对比度降低。

表 1.测试集 sCT 和 CBCT 图像的定量评价结果.

	CBCT	CycleGAN	Unet	CGAN
ME (HU)	1.12±3.22	10.44±3	3.17±0.6	0.29±0.95
MAE (HU)	14.01±2.7	22.73±2.34	8.64±1.49	7.77±1.32
MSE	8.1±2.43	20.64±2.27	4.88±1.35	4.99±1.3
PSNR	50.14±1.54	47.77±0.68	52.72±1.48	54.95±1.48
SSIM	0.93±0.02	0.88±0.01	0.96±0.01	0.96±0.01

表 2.测试集 sCT 和 CBCT 图像的局部定量评价结果.

		CycleGAN	Unet	CGAN
高对比度区	MAE (HU)	98.05±139.5	31.05±37.41	30.04±22.04
	PSNR	18.26±6.24	25.56±10.49	24.86±14.32
	SSIM	0.44±0.41	0.79±0.18	0.75±0.19
低对比度区	MAE (HU)	45.83±20.49	16.49±9.1	23.72±15.37
	PSNR	19.23±9.93	28.54±11.2	25.97±15.08
	SSIM	0.39±0.25	0.74±0.15	0.69±0.17

表 3.dCT、CBCT 和 sCTs 的骨和软组织空间不均匀性.

	dCT	CBCT	CycleGAN	Unet	CGAN
Bone	0.3476	0.2532	0.4544	0.1254	0.098
Soft tissue	0.0928	0.2204	0.1313	0.0749	0.0361

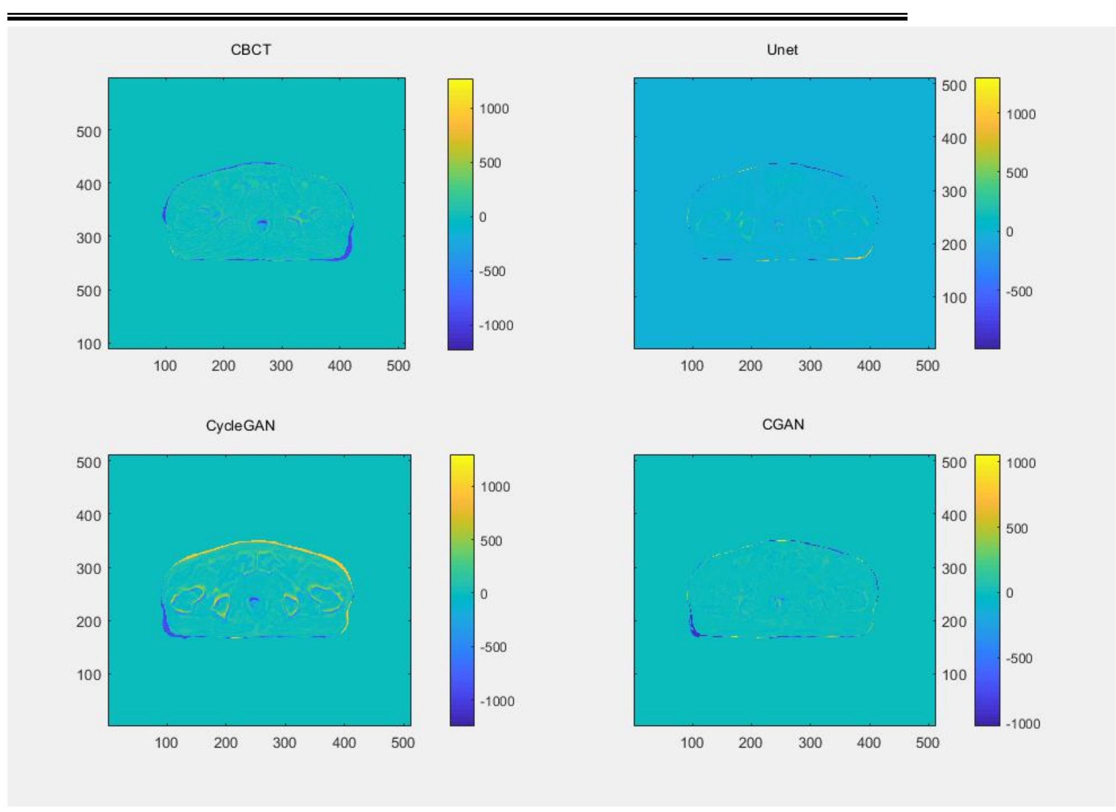


图 5. dCT 图像相对于 CBCT 与各 sCT 对应 CT 值差图。

图 5 提供了一个测试患者在 dCT 与 CBCT 和 sCT 之间 HU 差异的比较。相对于 dCT，每张 CT 图像都附有相应的 HU 差图。在四种模型中，cycleGAN 的精度较差，其全局 HU 值的差异最大。相比之下，CGAN 表现出最好的性能，与 dCT 差值最小。

4. 讨论和结论

本文以三种常见的深度学习模型作为基础，在实际应用中进行了比较，通过定量分析得出 CGAN 模型更适合开展基于 CBCT 的自适应放疗的结论。

Unet 模型作为一种经典模型，在图像处理分析中运用广泛。明鑫[15]等利用该模型实现了低能 CBCT 图像转换成高能 CBCT 图像，该预测高能图像的各项指标均与真实高能图像

接近。本文在利用该模型生成 sCT 时 ME 相较于 CBCT 会有一定提高，可能是该模型在学习的过程中会默认的提高图像的 CT 值，从而引起该误差的增加。宋新宇等[16]研究了一种基于该模型的自动勾画模型，能够快速完成 CBCT 图像上的临床 CTV 和危及器官 OAR 自动勾画工作。以上研究均表明了 Unet 模型在处理 CBCT 图像中的优异表演。本研究是利用 CBCT 生成 sCT，最终目的也是实现自适应放疗，因此后期研究可以考虑将生成 sCT 与自动勾画进行序贯学习，提高转换工作效率。

此前有大量利用 GAN 模型生成合成 CT 的相关研究。GAN 模型的优势在于它是一种以半监督方式训练的方法,适合标签较少的训练数据[17]，而且 GAN 模型只用到了反向传播,不需要复杂的马尔可夫链。李甫鹏[18]等通过对 GAN 及其他深度学习模型的研究，辅助高能物理领域的数据计算。其他的深度学习网络如 CycleGAN、CGAN、DCLGAN 等都是基于 GAN 模型开发的新方法。亓孟科等[19]开展了利用生成对抗网络建立头颈部肿瘤磁共振图像(Magnetic Resonance Imaging，MRI)与 CT 图像的映射模型的研究，提出并实现了使用 GAN 模型进行鼻咽癌患者 sCT 的生成，图像质量与剂量学比较均显示了方法的可行性与准确性，为磁共振图像引导放射治疗的实施开发了新的思路。刘宇翔等[20]则利用瓦里安 OBI(On-Board Imager)收集的 CBCT 图像，对比了三种深度学习方法的合成 CT 图像质量，结果显示使用 U-net、Pix2PixGAN 和 CycleGAN 模型生成图像的 MAE 分别为(29.4±16.1)、(37.1±14.4)、(34.3±17.3)HU。在图像质量方面，CycleGAN 模型生成的图像保留了 CBCT 图像结构且改善了图像质量，而 Unet 和 Pix2PixGAN 模型生成的图像存在过度模糊的问题，导致了图像失真，与本文基于 Unet 模型生成的 sCT 对比度低结论相同。本文中的 CycleGAN 模型 MAE 为 22.73±2.34，相较于 CBCT 反而升高了，可能是该模型在前列腺等软组织部位的学习不好，反而得到较差的表现。

前列腺区域的组织结构以肌肉和软组织为主，耻骨和盆骨的影像表现清晰，在 CBCT 中不易分辨前列腺与周边组织和脂肪。张帅楠等[21]通过对模体和临床实例的研究，证明了在前列腺图像引导放疗中 CBCT 为合成 CT 提供质量保证，并研究了体外实验中 CT 值与电子密度的曲线函数。因此利用 CBCT 生成合成 CT 非常有必要观察其低对比度区域的表现。Unet 模型在学习时会将 HU 值平均化处理，在低对比度区域中，该缺点反而成为了优势，使其获得更好的训练结果。

CBCT 与 CT 图像同属于同模态医学图像，相比于 MRI 图像，其纹理特征信息相对较少，同时 CBCT 图像内存在的伪影及噪声使得伪图像合成任务具有一定的难度。[22]然而，即使对于同一患者，也很难在 CBCT 和 pCT 之间实现足够准确的对齐，因为这些图像是在不同的日期获得的，往往会间隔几天或几周[8]。在改进的 CBCT 图像中，配对图像之间的不对齐会导致边缘模糊、变形和一些解剖结构消失等错误。因此我们需要不断更新自己的学习网络，保证所有的情况都可以学习到。

综上所述，由 CGAN 模型生成的 sCT 在整体上有更优的影像质量，更具应用于自适应治疗计划的潜力，为临床工作提供更好的服务。

5. 参考文献

[1]. Berger T, Jørgen Breede B P, etal.2017. Impact of bowel gas and body outline variations on total accumulated dose with intensity-modulated proton therapy in locally advanced cervical cancer patients Acta Oncol. 56 1472-8.
[2]. Jaju PP, Jain M, Singh A, Gupta A. Artefacts in cone beam CT. Open J Stomatol. 2013;03(05):292-297.
[3]. Chen L, Liang X, Shen C, Jiang S, Wang J. Synthetic CT generation from CBCT

images via deep learning. Med Phys. 2020;47(3):1115-1125.
[4]. Kida S, Nakamoto T, Nakano M, et al. Cone beam computed tomography image quality improvement using a deep convolutional neural network. Cureus. 2018;10(4):e2548.
[5]. Landry G, Hansen D, Kamp F, et al. Comparing Unet training with three different datasets to correct CBCT images for prostate radiotherapy dose calculations. Phys Med Biol. 2019;64(3):035011.
[6]. Li Y, Zhu J, Liu Z, et al. A preliminary study of using a deep convolution neural network to generate synthesized CT images based on CBCT for adaptive radiotherapy of nasopharyngeal carcinoma. Phys Med Biol. 2019;64(14):145010.
[7]. Harms J,Lei Y,Wang T,et al.Paired cycle-GAN-based image correction for quantitative cone-beam computed tomography. Med Phys. 2019;46(9):3998-4009.
[8]. Kida S, Kaji S, Nawa K, et al. Visual enhancement of conebeam CT by use of CycleGAN. Med Phys. 2020;47(3):998-1010.
[9]. Liang X, Chen L, Nguyen D, et al. Generating synthesized computed tomography (CT) from cone-beam computed tomography (CBCT) using CycleGAN for adaptive radiation therapy. Phys Med Biol. 2019;64(12):125002.
[10]. Liu Y, Lei Y, Wang T, et al. CBCT-based synthetic CT generation using deep-attention cycleGAN for pancreatic adaptive radiotherapy.Med Phys.2020;47(6):2472-2483
[11]. Zhang Y, Yue N, Su MY, et al. Improving CBCT quality to CT level using deep learning with generative adversarial network. Med Phys. 2021;48(6):2816-2826.
[12]. Zhu J-Y, Park T, Isola P, Efros A A, Unpaired image-to-image translation using cycle-consistent adversarial networks. IEEE International Conference on Computer Vision (ICCV). 2017; pp.2242-2251.
[13]. Zhang Y, Ding SG, Gong XC, et al. Generating synthesized computed tomography from CBCT using a conditional generative adversarial network for head and neck cancer patients. Technol Cancer Res Treat. 2022;21:15330338221085358.
[14]. 张欢, 仇大伟, 冯毅博, 刘静. U-Net 模型改进及其在医学图像分割上的研究综述[J]. 激光与光电子学进展, 2022, 59(2): 0200005.
[15]. 明鑫，杨成文，孟慧鹏，等。基于 U-Net 模型从低能锥形束 CT 图像实现高能成像的研究[J]．中华放射医学与防护杂志，2023, 43(9): 741-746.
[16]. 宋新宇，张翔宇，李京，等．前列腺癌自适应放疗中基于深度学习的 CBCT 临床靶区及危及器官自动勾画[J]．中国医疗器械杂志，2022, 46(6):691-695.
[17]. 左超, 冯世杰, 张翔宇, 等. 深度学习下的计算成像:现状、挑战与未来[J]. 光学学报, 2020, 40(1): 0111003.
[18]. 李甫鹏,庞龙刚,王新年.基于机器学习的重离子碰撞中 QCD 相变的研究[J].核技术, 2023,46(04):040014-040014.
[19]. 亓孟科, 李永宝, 吴艾茜, 等. 基于生成对抗网络的鼻咽癌患者伪 CT 合成方法研究[J]. 中华放射肿瘤学杂志, 2020, 29(4): 267-272.

[20]. 刘宇翔,杨碧凝,魏然等. 锥形束 CT 生成伪 CT 的深度学习方法[J]. 中华放射肿瘤学杂志, 2023, 32(1): 42-47.
[21]. 张帅楠,田龙,赵鑫.前列腺癌图像引导放疗中锥形束 CT 为合成 CT 提供质量保证的可行性研究[J].医疗卫生装备, 2023.
[22]. 孙鸿飞, 倪昕晔, 杨建华. 基于深度学习方法的伪 CT 图像合成技术研究及在放疗中的应用进展[J]. 中华放射医学与防护杂志, 2021, 41(3): 222-228.